

基于自学习中枢模式发生器的仿人机器人适应性行走控制

刘成菊¹ 耿焯东¹ 张长柱¹ 陈启军¹

摘要 为了克服传统中枢模式发生器 (Central pattern generator, CPG) 关节空间控制方法的复杂性和局限性, 本文基于自学习中枢模式发生器模型, 提出了一套在线调制和融合多传感器信息的仿人机器人环境自适应行走控制方法. 算法难点在于如何在机器人的工作空间将自学习 CPG 用于工作空间轨迹生成, 并使 CPG 参数直接和步态模式相关联. 本文提出了利用自学习 CPG 来学习和实时生成机器人质心轨迹和脚掌轨迹的方法, 在线调节机器人步长、抬腿高度和步行速度等关键参数. 参考生物反射行为, 利用传感反馈信息激发 CPG 以产生具有环境适应性的工作空间轨迹, 提升行走质量. 控制系统的参数通过优化算法来进一步改善行走性能. 相比于传统的 CPG 关节空间法, 本文所采用的自学习 CPG 工作空间法不仅极大简化了 CPG 网络结构而且提高了仿人机器人行走的适应性. 最后, 通过仿人机器人坡面适应性行走的仿真和实验, 验证了所提出控制策略的可行性和有效性.

关键词 仿人机器人, 自学习中枢模式发生器, 适应性行走, 轨迹生成

引用格式 刘成菊, 耿焯东, 张长柱, 陈启军. 基于自学习中枢模式发生器的仿人机器人适应性行走控制. 自动化学报, 2021, 47(9): 2170–2181

DOI 10.16383/j.aas.c190087

Adaptive Locomotion Control of Humanoid Robot Based on Self-Learning CPG

LIU Cheng-Ju¹ GENG Wan-Dong¹ ZHANG Chang-Zhu¹ CHEN Qi-Jun¹

Abstract To overcome the complexities and limitations of the joint-space CPG (central pattern generator)-inspired control methods, a novel CPG inspired workspace control strategy is presented in this work, where humanoid adaptive workspace trajectories is generated online through the self-learning CPG (SL-CPG). The challenge of this work is that how to generate the workspace trajectory of the humanoid robot in the workspace via SL-CPG and how to directly connect the SL-CPG parameters with the walking gait mode. In this paper, a novel method to generate the foot trajectory and center of mass (CoM) trajectory by using two sets of SL-SPG is proposed, and in this way some key parameters such as robot step size, leg height, and walking speed can be adjusted online. The resultant workspace trajectories can be adjusted by the sensory information, which mimics the vestibular reflex of animals. Furthermore, an evolutionary algorithm is developed to tune the control system parameters to improve the walking performance. Compared with the traditional CPG joint-space methods, the SL-CPG workspace method adopted in this paper not only greatly simplifies the CPG network structure but also improves the adaptability of humanoid robot walking. Finally, the applicability of the proposed control strategy is demonstrated through simulations and experiments focusing on the humanoid robots gait pattern adaptation over sloped terrain.

Key words Humanoid robot, self-learning central pattern generator (SL-CPG), adaptive walking, trajectory generation

Citation Liu Cheng-Ju, Geng Wan-Dong, Zhang Chang-Zhu, Chen Qi-Jun. Adaptive locomotion control of humanoid robot based on self-learning CPG. *Acta Automatica Sinica*, 2021, 47(9): 2170–2181

仿人机器人具有双手、双足、躯干等人类外形特征, 无需改造就能适应人类日常环境和使用工具, 更容易成为辅助人类生活、工作和完成危险作业的帮手, 因此可认为是下一代服务机器人最典型、最

友好的本体特征. 行走控制是仿人机器人的基础科学问题, 但仿人机器人自由度多、传感器多, 是一个不稳定的非线性强耦合动力学系统, 行走的自然性、环境适应性、突发环境变化时的平衡控制是长期困扰仿人机器人发展和应用的难题. 目前, 行走控制方法主要基于编程作业机制, 使得仿人机器人的本体特性不能得到充分的发挥^[1]. 普遍采用的基于零力矩点 (Zero moment point, ZMP) 的步行控制方法^[2–7], 允许机器人按照预先设计的轨迹行走并保持平衡, 但是由于预先设计的轨迹是固定的, 一旦地形发生变化, 则机器人无法完成行走任务. 对于机器人的环境适应性行走控制, 需要具有自适应产生轨

收稿日期 2019-02-14 录用日期 2019-04-30
Manuscript received February 14, 2019; accepted April 30, 2019
国家自然科学基金 (62173248, U1713211, 61673300), 浦东新区科技发展基金 (PKX2019-R18) 资助
Supported by National Natural Science Foundation of China (62173248, U1713211, 61673300) and Pudong New Area Science and Technology Development Fund (PKX2019-R18)
本文责任编辑 刘艳军
Recommended by Associate Editor LIU Yan-Jun
1. 同济大学电子与信息工程学院 上海 201804
1. College of Electronics and Information Engineering, Tongji University, Shanghai 201804

迹的能力。

改变传统的思维模式, 研究和抽象生物的行迹机理并加以模仿, 可能是突破机器人行走控制瓶颈的有效途径。该思想也引起相关学者的广泛关注, 其中, 比较著名的方法是基于中枢模式发生器 (Central pattern generator, CPG) 的生物诱导的机器人行走控制方法^[8-13]。由于其突出的适应性优势已经广泛应用在机器人运动控制中, 特别是在游泳、爬行、多足机器人的运动控制中取得了成功实验效果^[14-21]。然而目前存在的 CPG 模型基本只能产生正弦或类似正弦的输出, 如 Hopf 模型^[22-23]、Kuramoto 模型^[24-25] 等。即使存在能够在一定程度上调整输出波形形状, 如 Matsuoka 模型^[26-28], 但是模型参数与输出波形的形状之间没有明确的对应关系, 只能通过试凑法不断地尝试。并且只能对输出进行简单调整, 无法准确模拟某一特定形状。在 Righetti 等^[29-30] 的工作启发下, 我们提出了一种基于快速傅里叶变换的自学习 CPG (Self-learning CPG, SL-CPG) 模型。提出的模型可以学习周期性任意形状输入信号, 解决了以往 CPG 模型输出上的局限性。自学习 CPG 模型可以通过调整参数在线平稳调整其输出频率和幅值, 为引入传感器信号提供了便利。

另一方面, 如何将 CPG 模型应用于机器人的节律运动控制是该研究的另一难点问题。目前 CPG 机器人生物诱导控制方法应用较多的是关节空间控制法。通常将一个 CPG 单元分配给一个自由度, 优化 CPG 拓扑网络, 生成多维协调信号, 直接控制关节运动实现运动控制。关节空间方法在爬行、游泳、多足等机器人上取得了突出的研究成果。但是仿人机器人自由度多、结构复杂, 如果直接将 CPG 分配到机器人关节空间, 利用 CPG 之间的相互耦合组成 CPG 网络, 网络庞大, 参数众多。一些学者将 CPG 和进化算法结合来实现仿人机器人的行走控制^[31-34], 参数的进化是 CPG 产生满足要求控制信号的关键, 但参数和 CPG 网络的输出轨迹的关系并不直观。部分学者探索在机器人的工作空间来有效利用 CPG 的适应性^[35-41], 取得了不错的实验效果。

基于学者们的前期研究, 我们提出了生物诱导的仿人机器人工作空间行走模型。本文中, 我们采用自学习 CPG 模型在线生成仿人机器人质心和脚掌轨迹。分别利用两组 SL-CPG, 通过对示例轨迹的训练学习, 形成可以在线调制的轨迹生成器。通过传感器测得机器人自身姿态信息作为轨迹发生器的反馈输入, 因此可以根据具体的地面环境适应性调节输出轨迹。机器人的行走速度、腿的支撑段和摆动段的时间、迈步跨度和抬腿高度等可以实时地调整, 这是实现环境适应性行走的重要前提条件。基于工作

空间的方法大大简化了 CPG 网络和参数整定, 不需要事先获得地形条件信息, 也不依赖于地形测量的距离传感器信息。仿人机器人坡面环境适应性行走实验验证了控制系统的有效性。

1 自学习 CPG 模型

自学习 CPG 模型采用分层式设计: 底层为记忆单元, 高层为协调单元。记忆单元负责学习关节的参考控制信号, 协调单元负责调整各关节的相位关系并完成步态控制。该模型与其他模型的主要区别在于把相位同步和关节的运动模式控制分离开来。将相位振荡器模型 (如 Kuramoto 模型) 作为新模型的协调单元, 仅用来产生相位同步的信息。而把关节的运动模式控制作为记忆单元单独进行设计。产生的关节控制信号不仅可以保证相位锁定还能实现各种关节运动模式。而记忆单元采用傅里叶级数的思想, 用有限次的谐波去逼近一个周期函数, 学习过程采用 Hebbian 学习方法, 可以在线学习任意输入, 并能够把学到的信息储存起来, 通过协调单元的调节作用, 产生合适的输出。

1.1 自学习 CPG 原理

任意一个周期函数都可以按傅里叶级数展开为

$$y(t) = a + \sum_{n=1}^{\infty} b_n \cos(n\omega t + \phi_n) \quad (1)$$

其中, a 是常数项, ω 是基波的角速度。 a 和 ω 很容易计算得到。去掉直流分量整理为

$$y'(t) = y(t) - a = \sum_{n=1}^{\infty} b_n \cos(n\omega t + \phi_n) \approx \sum_{n=1}^i b_n \cos(n\omega t + \phi_n) \quad (2)$$

其中, i 是整数, $i \geq 1$ 。因此 b_n 和 ϕ_n 如果确定, 那么前 i 个谐波和就可以用来近似 y' 。

自学习 CPG 的基本思想如图 1 所示。每个圆代表具有自学习能力的谐波。 y' 代表需要学习的示例轨迹, P 代表系统的输出, F 是 y' 与 P 的差值。随着学习训练的进行, P 将逐渐趋向于 y' , F 趋向于 0, 由于忽略了高次谐波, F 最终不会为 0。但是如果采用足够多的谐波, F 将足够小, 可以近似于 0, 此时对系统的影响可以忽略不计。这也就意味着系统的输入和反馈可以切断, 系统的输入为 0, 学习过程停止, 系统变为一个自治的系统, 系统的输出 P 虽然和 y' 有轻微变化, 但非常接近 y' 。基于此, CPG 模型可以学习和生成任意周期性信号。

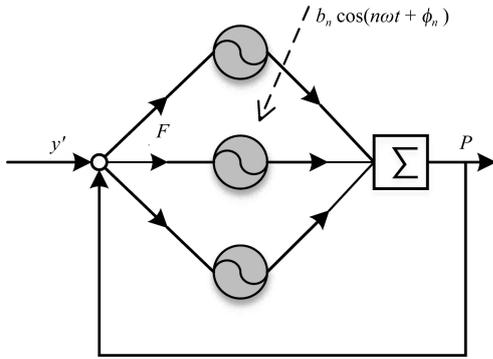


图1 自学习 CPG 模型学习基本过程

Fig.1 Basic learning process of SL-CPG model

1.2 CPG 模型数学描述

1.2.1 Hopf 振荡器模型

Hopf 振荡器易于独立调节波形的幅值和频率, 因此本文采用 Hopf 振荡器设计自学习 CPG 模型, Hopf 振荡器描述如下:

$$\begin{aligned} \dot{x} &= (\mu - r^2)x - \omega y \\ \dot{y} &= (\mu - r^2)y + \omega x \end{aligned} \quad (3)$$

其中, $r = \sqrt{x^2 + y^2}$, $\mu > 0$, $\omega > 0$, μ 和 ω 分别控制幅值和频率.

1.2.2 幅值学习

在 Hopf 振荡器模型中加入一个扰动项 εF , 则式 (3) 变为

$$\begin{aligned} \dot{x} &= (\mu - r^2)x - \omega y + \varepsilon F \\ \dot{y} &= (\mu - r^2)y + \omega x \end{aligned} \quad (4)$$

其中, $F = P - y'$, ε 为常数. 进行变量替换, 令 $x = r \cos(t)$ 和 $y = r \sin(t)$, 式 (4) 变为

$$\begin{aligned} \dot{r} &= (\mu - r^2)r + \varepsilon F \cos(\phi) \\ \dot{\phi} &= \omega - \frac{\varepsilon}{r} F \sin(\phi) \end{aligned} \quad (5)$$

观察式 (2), 需要确定的变量就是幅值 a 和相角 $n\omega t + \phi_n$. 而在式 (5) 中, μ 控制幅值, ϕ 是极坐标系下极角变量, 相角可以直接通过 ϕ 得到. 对于如何得到 μ , 我们借助于 Hebbian 学习, 设计了一个新的变量 α 来取代 μ , 使得 α 也变成一个动态项, 来学习输入信号的幅值, 如式 (6) 所示.

$$\begin{aligned} \dot{r}_n &= (\alpha_n - r_n^2)r_n + \varepsilon F \cos(\phi_n) \\ \dot{\phi}_n &= n\omega - \frac{\varepsilon}{r_n} F \sin(\phi_n) \\ \dot{\alpha}_n &= \eta r_n F \cos(\phi_n) \end{aligned} \quad (6)$$

其中, η 是学习率, ω 是基波角速度, 可以通过对输出信号 y' 进行快速傅里叶变换得到, n 代表第 n 次谐波. 最终采用式 (6) 完成对周期性信号 y' 的学习, 系统的输出如下:

$$P = \sum_{n=1}^i r_n \cos \phi_n \quad (7)$$

1.2.3 保持模型内相位同步

经过上面的步骤, 已经得到了一个能够学习任意周期波形的模型, 但这只是一个最基本的模型, 要实际应用还需要进一步改进. 主要的问题在于: 无法调整该模型输出波形的相位. 我们不仅要控制一个关节, 而是要同时控制多个关节并协调它们之间的相位使之满足一定的步态. 因此, 如果不能调整任一输出的相位, 模型间是不能协调工作的, 也就不能用来控制行走. 所以, 单个模型必须能够根据上一层的控制信号改变输出波形的相位.

根据设计的模型, 每个输入都是由一组谐波叠加进行逼近的, 当学习结束时, 这组谐波之间其实也形成了一定的相位关系. 如果在上层控制信号发出改变输出波形相位的命令后, 这个相位关系还能够一直保持, 那么就能保证调整相位后, 输出波形的形状不变. 因此, 首先要记录这个学习到的相位关系, 另外, 还要能够保持这个相位关系.

定义 $\theta_n = \phi_n - n\phi_1$, θ_n 表示学习完成以后第 n 次谐波与基波之间的相位差. 当 F 设置为 0 之后, θ_n 将不再发生变化. 采用 Kuramoto 模型的方法, 此时学习结束后的模型为

$$\begin{aligned} \dot{r}_n &= (\alpha_n - r_n^2)r_n \\ \dot{\phi}_n &= n\omega - \lambda \sin(-n\phi_1 - \theta_n + \phi_n) \end{aligned} \quad (8)$$

当有高层信号使得基波相位发生变化时, 其他谐波相位也会立刻跟随基波相位发生变化, 最终保持之前的相位关系. 因此叠加之后的波形除了相位产生了平移, 波形形状保持不变.

1.2.4 保持模型间相位同步

通过加入 Kuramoto 项, 保持了谐波与基波间的相位差, 当基波相位发生变化时, 各次谐波的相位能进行跟随, 因此保证了模型能够输出正确的波形. 为了保持各自学习 CPG 之间的相位差, 也就是各模型间的相位差, 只需要另外加入 Kuramoto 项, 使相互有连接关系的模型基波之间保持一定的相位差.

1.3 自学习 CPG 的参数调制

当自学习 CPG 模型完成对示例信号的训练学习后, 模型成为一个自治系统. 在式 (8), α_n 和 ω 分别影响 CPG 输出的幅值和频率. 引入幅值调节系数

k_α , 频率调节系数 k_ω 和直流分量调节系数 k_a 如式 (9) 所示, 可以分别独立调节幅值和频率分别为示例轨迹的 k_α 和 k_ω 倍, 这有利于自学习 CPG 根据不同控制需求产生适应性的轨迹.

$$\begin{aligned} \dot{r}_n &= (k_\alpha^2 \alpha_n - r_n^2) r_n \\ \dot{\phi}_n &= nk_\omega \omega - \lambda \sin(-n\phi_1 - \theta_n + \phi_n) \\ P &= \sum_{n=1}^i \cos \phi_n + k_a \end{aligned} \quad (9)$$

图 2 表示自学习 CPG 模型对一个示例轨迹的学习情况, 其中虚线代表示例轨迹, 实线代表自学习 CPG 模型的输出. 当为 $t < 4s$ 时为模型学习阶段, 当 $t = 4s$ 时, 模型学习完成, 取消示例轨迹的输入, 此时自学习 CPG 仍然能够按照示例轨迹的形状继续生成.

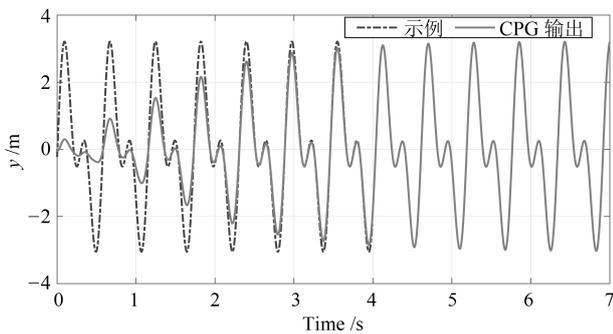


图 2 自学习 CPG 学习结果

Fig. 2 The learning results of SL-CPG

图 3 表示训练完成后分别调节幅值和频率调节 CPG 的输出. 在 $t = 0 \sim 0.6s$, $k_\alpha = 1$ 和

$k_\omega = 1$, CPG 输出保持和参考轨迹相同的幅值和频率; 在 $t = 0.6 \sim 1.6s$, $k_\alpha = 0.5$ 和 $k_\omega = 1$, CPG 输出幅值为参考轨迹的一半, 频率相同; 在 $t > 1.5s$, $k_\alpha = 1$ 和 $k_\omega = 0.5$, CPG 输出幅值和参考轨迹的相同, 频率是参考轨迹的一半.

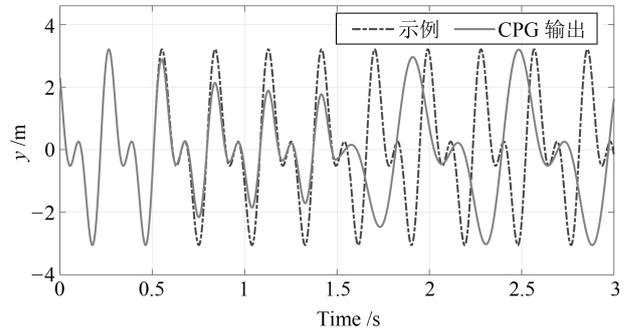


图 3 自学习 CPG 参数调制

Fig. 3 The parameters modulation of SL-CPG

2 控制系统设计

本文提出的仿人机器人适应性行走的控制系统的整体构架如图 4 所示, 自学习 CPG 轨迹发生器包括质心、脚掌轨迹发生器和运动引擎.

2.1 质心轨迹发生器

利用自学习 CPG 模型对示例的仿人行机器人行走时的轨迹进行训练学习, 能够得出机器人的三维质心轨迹发生器, 质心轨迹在垂直方向上与摆动脚在垂直方向规律一致, CoMz 上轨迹由摆动脚轨迹映射得出. 这里采取两个自学习 CPG 模型来训练学

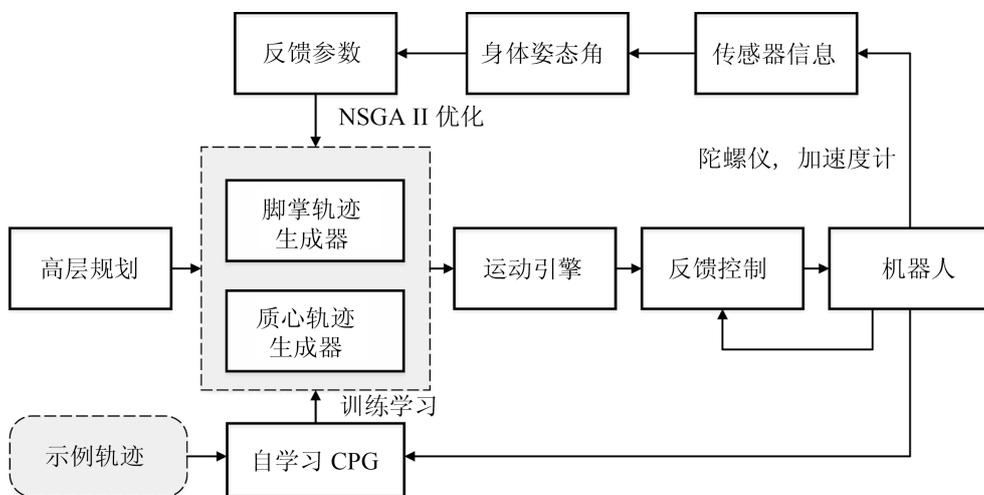
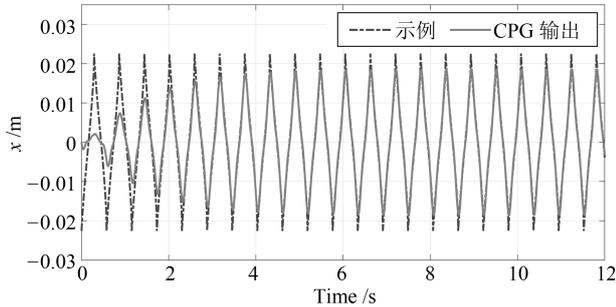


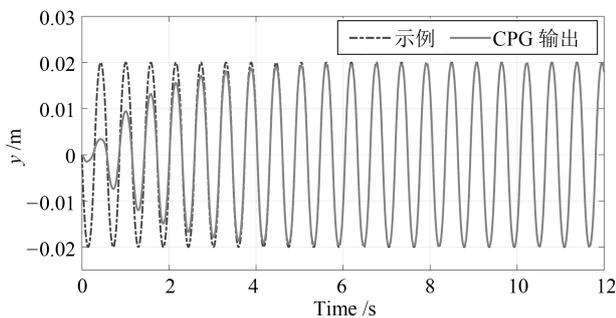
图 4 整体控制系统构架

Fig. 4 The architecture of the control system

质心在 x 和 y 方向上的运动, 为保持轨迹的同步性, 两个发生器之间的相位差设为 0. 图 5 和图 6 分别表示机器人 x 方向和 y 方向的上质心的轨迹, 其中虚线表示示例轨迹, 实线表示自学习 CPG 模型的输出轨迹.



(a) 质心 x 方向轨迹生成
(a) Generation of CoM x trajectory



(b) 质心 y 方向轨迹生成
(b) Generation of CoM y trajectory

图 5 质心 x 方向和 y 方向轨迹生成

Fig. 5 The generated CoM x and CoM y trajectories

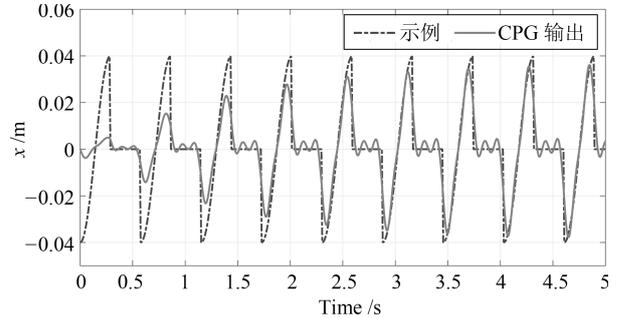
2.2 脚掌轨迹发生器

机器人在行走时, 摆动脚的轨迹在 y 方向上是恒定的, 所以只需要训练两个维度的轨迹. 和质心轨迹的训练类似, 同样采用了两个自学习 CPG 模型, 分别在 x 和 z 方向上进行训练, 这两个方向的幅值分别表示了行走的步幅和迈步的跨度, 所以通过调节 CPG 的参数, 可以很方便地调节机器人行走的上述参数. 机器人在行走过程分为左脚支撑阶段和右脚支撑阶段, 在每只脚对应的支撑阶段脚掌轨迹为一段直线, 自学习 CPG 针对连续直线的学习会有较大的误差.

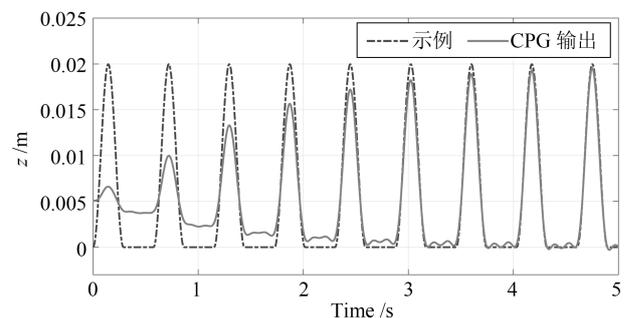
本文采用双脚摆动轨迹联合的改进思路, 把双脚摆动轨迹联合, 只学习摆动阶段轨迹, 然后通过对左右脚支撑的判断, 实现双脚轨迹的分离.

图 6 (a) 和 6 (b) 为改进前自学习 CPG 模型分别对脚掌轨迹的 x 和 z 方向的学习结果, 在直线段有明显的误差. 图 7 (a) 和 7 (b) 为改进后自学习

CPG 模型分别对脚掌轨迹的 x 和 z 方向的学习结果, 每幅图的上半部是左右脚联合的摆动阶段轨迹, 下半部是轨迹分离后单脚的轨迹. 其中虚线为示例轨迹, 实线为自学习 CPG 脚掌轨迹生成器输出轨迹.



(a) 改进前脚掌 x 方向轨迹学习
(a) Foot x -direction trajectory learning before improvement



(b) 改进前脚掌 z 方向轨迹学习
(b) Foot z -direction trajectory learning before improvement

图 6 CPG 模型改进前脚掌 x 方向和 z 方向轨迹学习结果

Fig. 6 The learning results of the x and z direction foot trajectories before CPG model improved

2.3 行走适应性

在人类坡面行走过程中, 会通过前庭反射来调制姿态, 例如身体质心的位置, 来避免倾覆. 实现机器人环境适应性的关键是如何通过对机器人自身状态和外部环境的感知所获得反馈信息, 实现运动控制系统的自我调节. 机器人身体姿态角度 θ_{pitch} 可以反映机器人的行走坡面情况, 因此以身体姿态角度作为反馈信息实时在线调制 CPG 的输出, 调整质心和脚掌轨迹的输出轨迹, 从而实现仿人机器人的坡面适应性行走控制, 反馈设计如图 8 所示.

2.4 运动引擎

在机器人系统中, 任务空间与关节空间的关系可描述为

$$T = f(\theta) \quad (10)$$

其中, $T = [T_1 \cdots T_M]^T$ 代表了末端的位置和姿

态, 而 $\theta = [\theta_1 \cdots \theta_N]^T$ 中的 θ_i 则表示了连杆 i 相对于连杆 $i-1$ 的转角或位移.

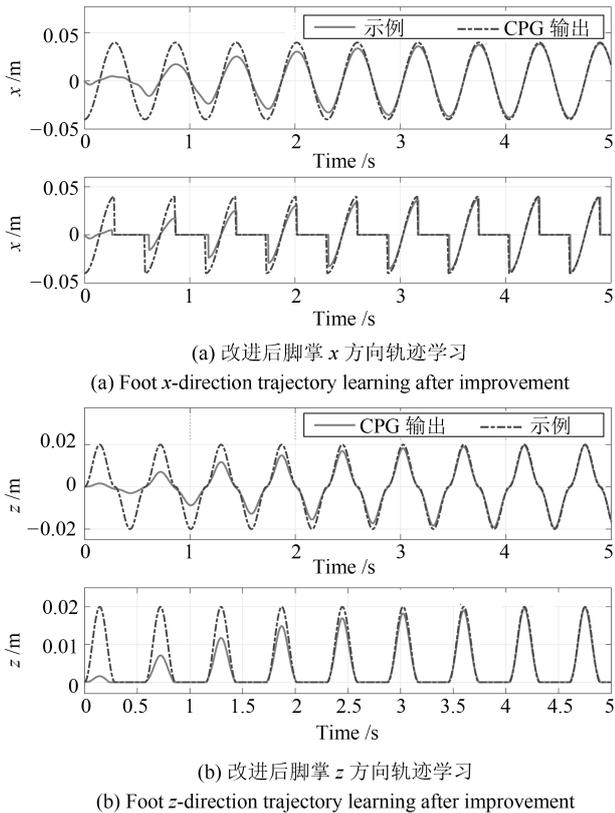


图 7 CPG 模型改进后脚掌 x 方向和 z 方向轨迹学习结果
Fig. 7 The learning results of the x and z direction foot trajectories after CPG model improved

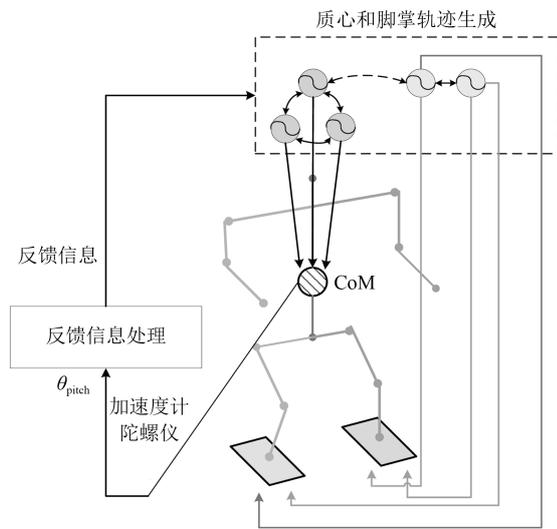


图 8 反馈控制回路框图

Fig. 8 The block diagram of feedback control loop

若利用分解速度控制法 (Resolved motion rate control, RMRC)^[42] 来控制关节的角速度, 可将机器人系统的微分运动学及逆微分运动学表示为

$$\dot{T} = J(\theta) \times \dot{\theta}$$

$$\dot{\theta} = J^{-1}(\theta) \times \dot{T} \quad (11)$$

其中, $J(\theta)$ 为雅可比矩阵, $J^{-1}(\theta)$ 为其逆矩阵.

如果 $N > M$, 则机器人系统是冗余的. 当雅可比矩阵非满秩时 (即系统为冗余时), 其逆矩阵不存在, 利用伪逆矩阵代替雅可比矩阵的逆矩阵^[43]:

$$J^\# = J^T (J J^T)^{-1} \quad (12)$$

为了防止奇异性问题, 可使用最小二乘法表示其伪逆矩阵为

$$J^\# = (J^T J + \lambda^2 I)^{-1} J^T \quad (13)$$

其中, 参数 λ 为阻尼系数, 保证雅可比矩阵 $J(\theta)$ 为满秩的.

基于微分逆运动学的机器人运动控制引擎的设计方法如图 9 所示, 其中 T^{ref} 和 T^{real} 代表参考轨迹和实际轨迹, J 代表雅可比矩阵, θ_{real} 是实际关节角.

3 仿真与实验

3.1 反馈回路设计

NAO 仿人机器人作为验证平台. NAO 高 58 cm, 装有 3 轴加速计和 2 轴陀螺仪, 有 25 个自由度, 本文只考虑两条腿上的 10 个自由度. 利用传感器陀螺仪和加速度计均可计算机器人的身体姿态角. 加速度计反映的是一种静态特性, 而陀螺仪反映的是一种动态特性. 由于机器人系统的高频振荡和传感器噪声的影响, 计算得到的身体姿态角度不能客观准确地反映机器人的姿态. 本文设计了一种补偿滤波器, 如图 10 所示, 加速度传感器计算的身体姿态角 θ_{acc} 通过低通滤波器滤掉高频部分, 陀螺仪计算出来的身体姿态角 θ_{gyro} 通过高通滤波器滤掉低频部分, 再将两者加权求和得到最终的身体姿态角 θ

$$\theta = \text{GainL} \times \text{LF}(\theta_{\text{acc}}) + \text{GainH} \times \text{HF}(\theta_{\text{gyro}}) \quad (14)$$

坡面实验环境设置包括上坡、平地以及下坡三种, 上下坡面的坡度设定为 10° 左右. 在上坡过程中, 机器人质心需要前倾, 避免发生打滑; 在下坡过程中, 机器人应后仰, 即质心稍滞后, 避免发生倾覆. 将身体姿态角作为自学习 CPG 产生质心轨迹 x 方向的反馈信息, 设计如下:

$$a'_{\text{CoM}x} = a_{\text{CoM}x} + K_a \times \theta$$

$$k'_{\alpha\text{CoM}x} = k_{\alpha\text{CoM}x} (1 - K_{\text{CoM}x} \times \theta) \quad (15)$$

反馈参数在学习过程中每轮都会更新, 式中, $a_{\text{CoM}x}$ 和 $k_{\alpha\text{CoM}x}$ 分别为自学习 CPG 在质心轨迹 x 方向

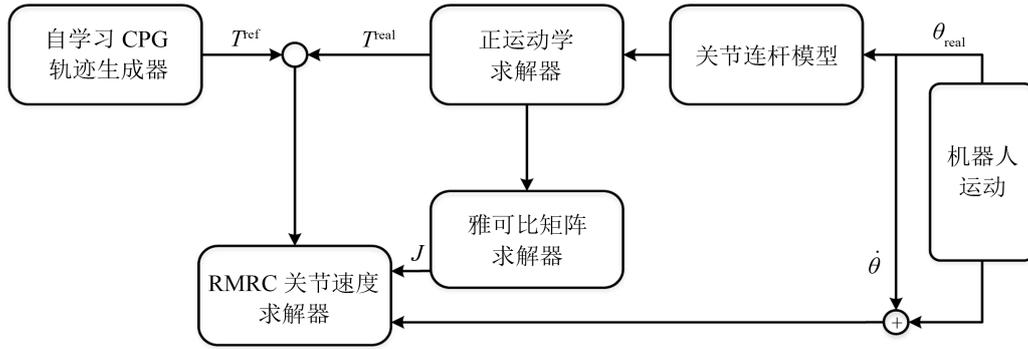


图 9 基于微分逆运动学的机器人运动控制引擎设计框图

Fig. 9 Block diagram of robot motion control engine based on differential inverse kinematics

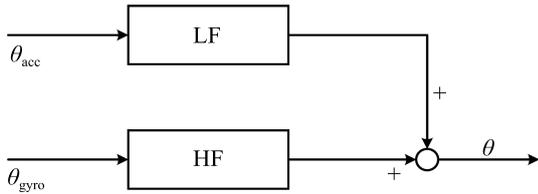


图 10 身体姿态角计算

Fig. 10 Calculation of body attitude

的直流分量和幅值调节系数, $a'_{\text{CoM}x}$ 和 $k'_{\alpha\text{CoM}x}$ 为更新后的系数. 对应的 K_a 和 $K_{\text{CoM}x}$ 分别是质心反馈增益系数.

机器人在进行坡面行走时, 迈步的跨度和高度反馈回路设计如下:

$$\begin{aligned} k'_{\alpha\text{Foot}x} &= k_{\alpha\text{Foot}x}(1 - K_{\text{Foot}x} \times \theta) \\ k'_{\alpha\text{Foot}z} &= k_{\alpha\text{Foot}z}(1 - K_{\text{Foot}z} \times \theta) \end{aligned} \quad (16)$$

其中, $k_{\alpha\text{Foot}x}$ 和 $k_{\alpha\text{Foot}z}$ 分别表示自学习 CPG 在脚掌轨迹 x 和 z 方向上的幅值调节系数, $k'_{\alpha\text{Foot}x}$ 和 $k'_{\alpha\text{Foot}z}$ 分别表示调节后的系数, $K_{\text{Foot}x}$ 和 $K_{\text{Foot}z}$ 分别表示两个方向上的反馈增益系数.

自学习 CPG 的质心和脚掌轨迹的频率均为同步的, 4 个自学习 CPG 中的频率反馈调节是统一的, 反馈设计如下:

$$k'_\omega = k_\omega(1 - K_\omega \times \theta) \quad (17)$$

其中, k_ω 为自学习 CPG 频率调节系数, K_ω 为对应的反馈增益系数, k'_ω 为反馈调节后的更新系数.

为了避免脚掌在运动时和地面发生摩擦, 使得机器人具有与人相似的步态, 机器人在坡面行走时, 脚掌的摆动角度和平地略有不同, 摆动脚的上下限会根据坡度发生变化, 主要是为了配合上文所提到的质心和脚掌轨迹的变化, 设计如下反馈:

$$\omega_{\text{sup}} = \begin{bmatrix} 0 & K_{\text{sup}} \times \theta & 0 \end{bmatrix}^T$$

$$\omega_{\text{sw}} = \begin{bmatrix} \omega_x \times l(t) & \omega_y \times l(t) + K_{\text{sw}} \times \theta & 0 \end{bmatrix}^T \quad (18)$$

其中, ω_{sup} 和 ω_{sw} 分别表示支撑脚和摆动脚的角度变化, ω_x 和 ω_y 表示平地行走时绕 x 和绕 y 方向上的最大值, $l(t)$ 为时间函数, 表示为 $l(t) = \sin(\frac{\omega \times \text{mod}(t, 2\pi/\omega)}{2})$, 其中 ω 为自学习 CPG 输出轨迹的频率, K_{sup} 和 K_{sw} 是反馈增益系数.

3.2 参数优化

为快速获取最佳的反馈控制参数, 本节基于 Deb 的 NSGA-II 算法^[44] 对控制系统进行优化. 本文用到了二元竞争选择, 中间交叉和高斯突变等方法, 实验的仿真是在 Webots 环境下进行. $fitness_{\text{atti}}$ 和 $fitness_{\text{dis}}$ 是设计的两个目标函数来联合优化质心和脚掌轨迹:

$$\begin{aligned} fitness_{\text{atti}} &= \sum (|\theta_{\text{pitch}}| + |\theta_{\text{roll}}|) \\ fitness_{\text{dis}} &= -distance_x(\text{robot}) \end{aligned} \quad (19)$$

其中, $fitness_{\text{atti}}$ 反映了机器人在整个行走过程的稳定性, $fitness_{\text{dis}}$ 代表在一次行走中机器人行走的最远距离.

本次实验中 NSGA-II 的种群规模为 50, 最大优化代数 200. 优化初期, NAO 在上坡的时候很容易摔倒, 经过约 40 代的时候, NAO 可以在坡面实现稳定的行走, 行走轨迹有可能会偏离直线. 图 11 为进化到 180 代的结果, 图中标记的点是选择的最优解. 表 1 中显示了对应的参数, 这些参数在实验中均保持相同.

3.3 坡面行走

3.3.1 固定坡度坡面行走仿真

仿真实验持续 83s, 图 12 表示在实验过程中身体姿态角 pitch 和 roll. 图 13 (a) 表明引入身体姿态作为反馈, 质心的位置可以在线调制, 当走上坡时,

CoM_x 沿斜面向前移动, 反之, 下坡时质心向后移动. 图 13(b) 所示为脚掌轨迹在线生成的 $x-z$ 平面轨迹, 迈步的高度和长度也根据坡面适应性调整, 当上坡时, 高度和长度根据反馈信息相应减少防止滑动, 反之下坡时相应增加, 防止倾覆. 图 14 是机器人坡面行走时 ZMP 的分布情况, 其中实线方框代表机器人脚部支撑区域, 虚线代表 ZMP, 整个实验过程 ZMP 均保持在机器人的支撑区域内. 图 15 是仿真实验过程的截图.

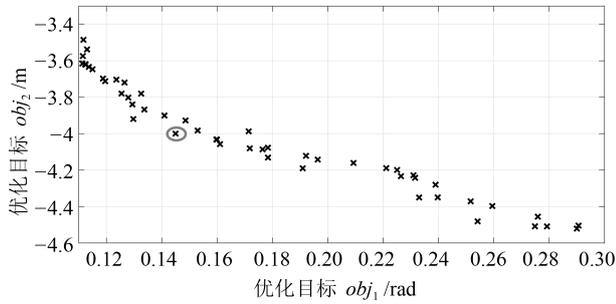


图 11 迭代 180 次 Pareto 前沿面
Fig. 11 Pareto front of generation 180

表 1 最优参数集

Table 1 Optimal parameters set

参数	值
K_a	0.0137
K_{CoM_x}	0.0384
K_{Foot_x}	0.0365
K_{Foot_z}	0.0401
K_ω	0.0212
K_{sw}	0.4813
K_{sup}	0.4677

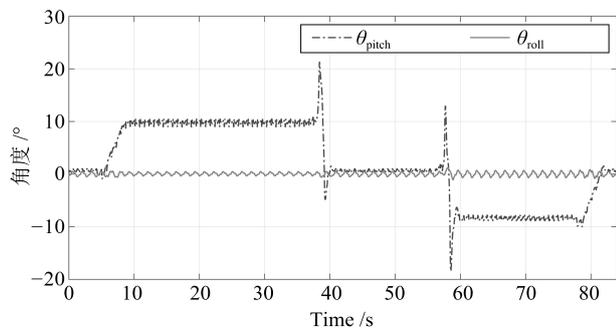
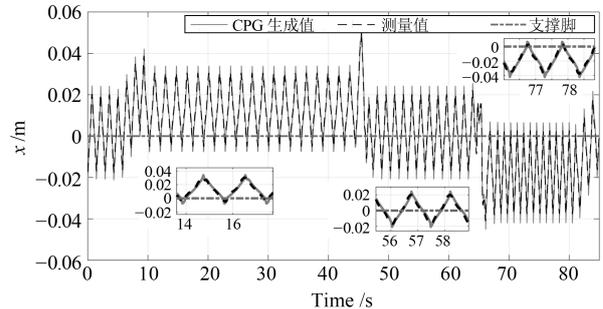


图 12 身体姿态角变化
Fig. 12 The body attitude angle

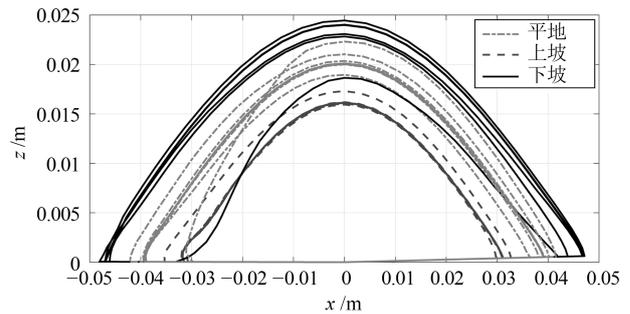
3.3.2 变坡度坡面行走仿真

本文设计的第二组实验是坡度连续增加的坡面,

坡面从从左至右坡度依次是 $4^\circ, 6^\circ, 8^\circ, 10^\circ$ 和 12° . 自学习 CPG 质心和脚掌轨迹发生器能根据坡面变化在线生成具有适应性的轨迹. 图 16 表示在坡度逐渐增加的坡面上身体姿态角的变化, 图 17 是整个实验过程的截图.



(a) 质心 x 方向轨迹
(a) CoM_x trajectory



(b) $x-z$ 平面下的脚掌轨迹
(b) Foot trajectory in $x-z$ plane

图 13 自学习 CPG 在线生成的质心 CoM_x 和脚掌轨迹
Fig. 13 Online generated CoM_x and foot trajectory by SL-CPG

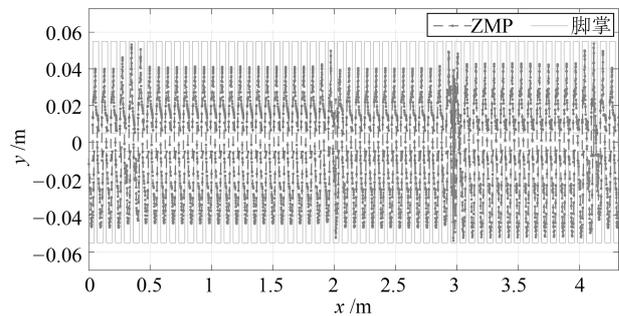


图 14 ZMP 分布
Fig. 14 ZMP distribution

3.3.3 与关节空间法对比分析

基于关节空间法, 在机器人行走时, 每一个自由度都需要一个 CPG 单元来控制, 需要 10 个 CPG 单元进行学习, 其结构如图 18 所示.

CPG 关节空间法成功实现了机器人平地的行走, 图 19 是机器人平地行走时 CPG 所产生的左腿的关节控制信号.

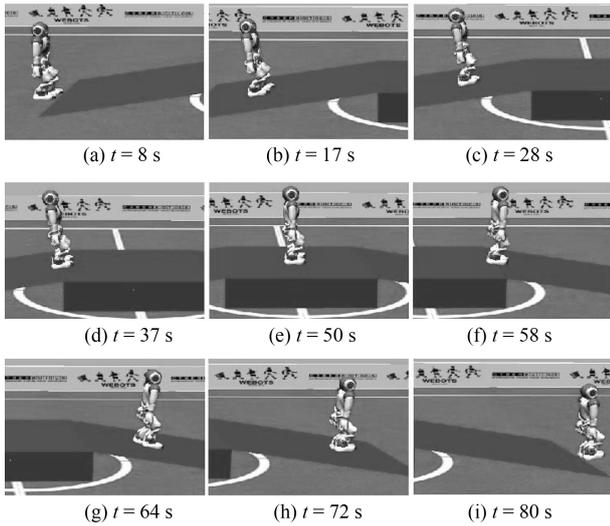


图 15 坡面行走仿真截图

Fig. 15 Snapshots of d slope terrain adaptive walking simulation experiment

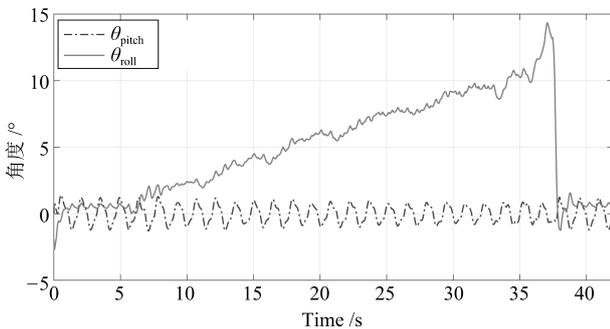


图 16 身体姿态角变化

Fig. 16 The body attitude angle

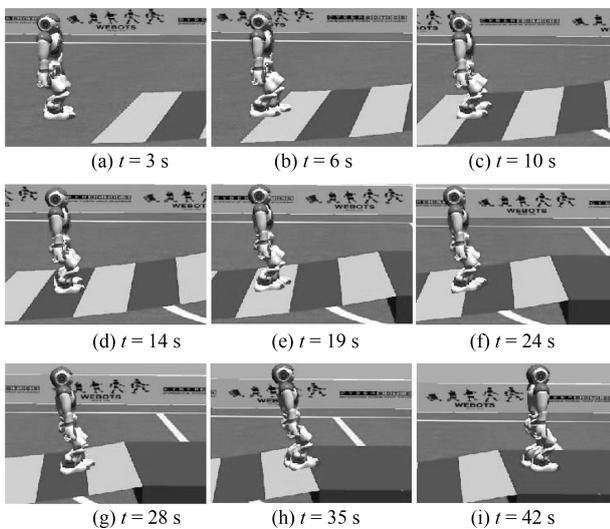


图 17 变坡度坡面仿真实验截图

Fig. 17 Snapshots of walking on varying slope

在坡面自适应行走实验中, 实验环境设置保持一致, 反馈的设置和 CPG 工作空间方法中相似:

$$k'_{\alpha\text{DoF}_i} = k_{\alpha\text{DoF}_i}(1 - K_{\text{DoF}_i} \times \theta)$$

$$k'_{\omega} = k_{\omega}(1 - K_{\omega} \times \theta) \quad (20)$$

其中, $k_{\alpha\text{DoF}_i}$ 和 k_{ω} 分别表示第 i ($i = 1, 2, \dots, 10$) 个自由度的 SL-CPG 单元的幅值和频率调节系数, K_{DoF_i} 和 K_{ω} 为反馈增益系数, K'_{DoF_i} 和 K'_{ω} 为反馈调节后的更新系数.

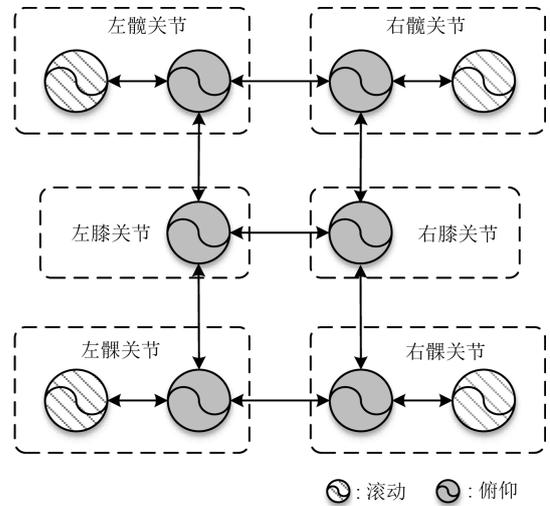


图 18 CPG 网络结构图

Fig. 18 Network structure of CPG

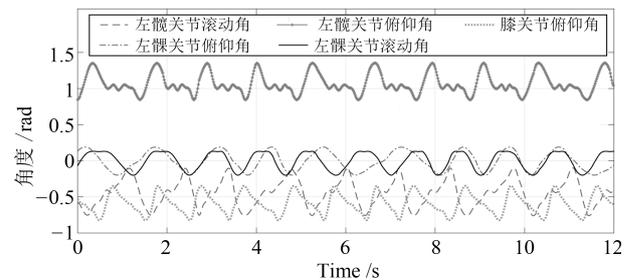


图 19 左腿关节控制信号

Fig. 19 Control signals of left leg joints

在坡面自适应实验中, CPG 关节空间法未能成功完成实验, 在 NSGA-II 优化算法结束后, 机器人仍然无法在坡面上实现稳定的自适应行走. 在关节空间法中, 机器人的质心变化是不可预测的, 会导致非正常的步态产生, 而且在平地行走中机器人的摇晃程度更大. 相比较于关节空间法, 本文所提出的工作空间法, 控制网络更为简单有效, 所需 CPG 单元和参数较少; 控制机器人的质心轨迹, 有效防止机器人滑倒和倾覆, 实现了机器人的自适应行走.

3.3.4 实体机器人实验

基于 Webots 中的仿真结果, 将程序移植到 NAO 实体机器人中, 测试其行走性能. 由于在 Webots 中没有绝对准确的动力学模型, 而且仿真和实际行走时的摩擦系数不同以及实际机器人存在损耗,

所以所设计的反馈回路的参数需要在相对小的范围内通过试验和误差来调制。

在本次试验中, 机器人依次连续通过三个不同的地形: 上坡, 平地 and 下坡, 其中上下坡的坡度均为 7° 左右. 机器人在未知地形情况下, 自学习 CPG 基于机器人自身的身体姿态来自动在线调整质心和脚掌的轨迹, 实现适应性行走. 图 20 是实验的截图, 图 21 是自学习 CPG 在线生成的质心和脚掌轨迹; 图 22 是机器人行走过程中 ZMP 的分布情况, 其中实线代表脚掌多边形, 虚线是 ZMP 分布.

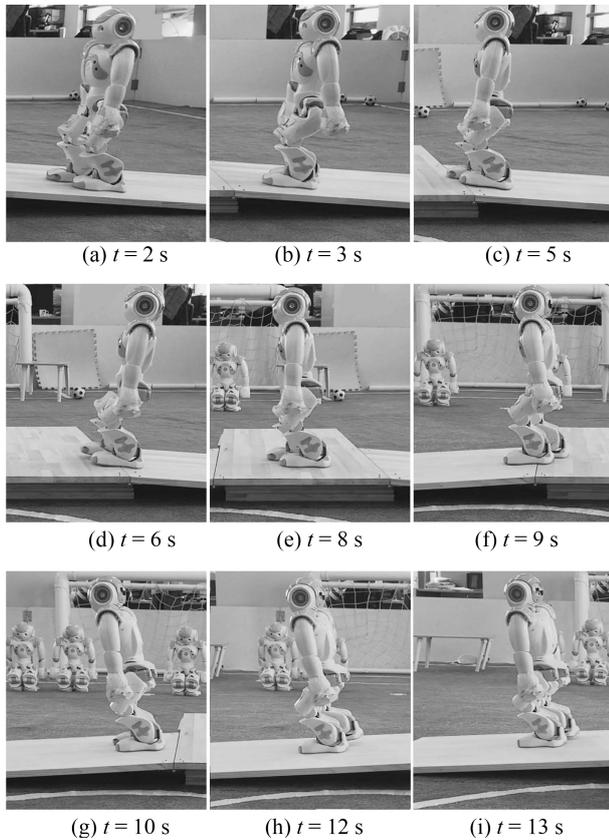


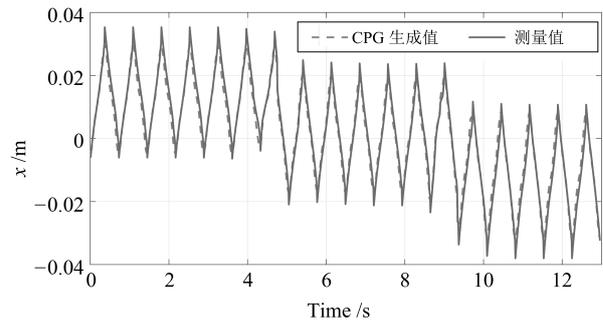
图 20 适应性行走实验截图

Fig. 20 Snapshots of adaptive walking experiment

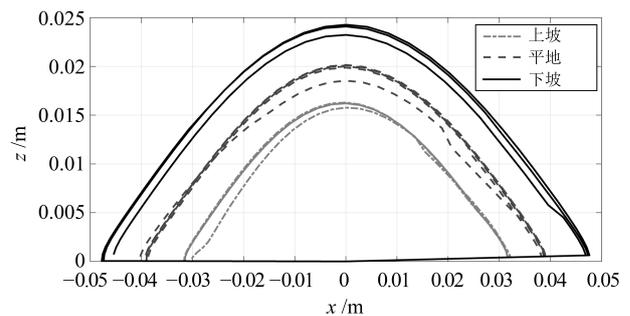
4 结束语

本文采用了 4 个自学习 CPG 单元分别对机器人的工作空间轨迹训练学习, 得到质心和脚掌的在线轨迹发生器. 自学习 CPG 工作空间规划方法, 可以从机器人现有轨迹或人类的行走步态中学习, 并模仿人类的前庭反射, 通过设计多个反馈回路来防止机器人发生打滑和倾覆. 仿真和实体实验以及与传统关节空间法的对照实验, 验证了所采用基于自学习 CPG 的轨迹学习和生成方法以及自适应行走控制策略的有效性. 本文提出的 SL-CPG 模型和工作空间轨迹生成方法对足式机器人具有普适性. 下

一步将研究反馈控制器的设计以及基于强化学习的参数进化算法, 并结合环境信息实现更为复杂地形及未知外部扰动下的自适应行走控制.



(a) 质心 x 方向轨迹
(a) CoM x trajectory



(b) x - z 平面下的脚掌轨迹
(b) Foot trajectory in x - z plane

图 21 自学习 CPG 在线生成的质心 CoM x 和脚掌轨迹
Fig. 21 Online generated CoM x and foot trajectory by SL-CPG

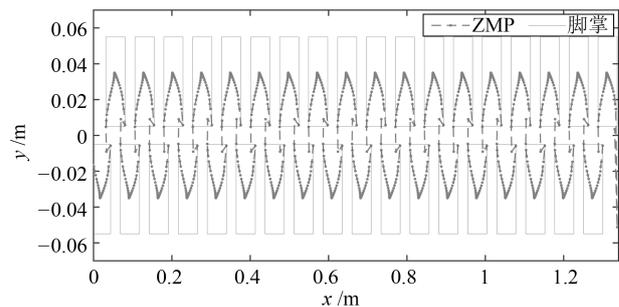


图 22 ZMP 分布

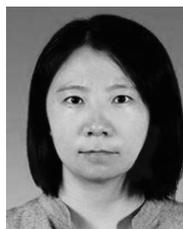
Fig. 22 ZMP distribution

References

- 1 Tian Yan-Tao, Sun Zhong-Bo, Li Hong-Yang, Wang Jing. A review of optimal and control strategies for dynamic walking bipedal robots. *Acta Automatica Sinica*, 2016, **42**(8): 1142–1157
(田彦涛, 孙中波, 李宏扬, 王静. 动态双足机器人的控制与优化研究进展. *自动化学报*, 2016, **42**(8): 1142–1157)
- 2 Vukobratović M, Borovac B. Zero-moment point—thirty five years of its life. *International Journal of Humanoid Robotics*, 2004, **1**(1): 157–173

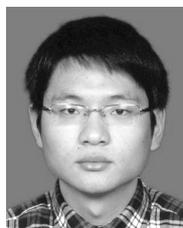
- 3 Huang Q, Yokoi K, Kajita S, Kaneko K, Arai H, Koyachi N, et al. Planning walking patterns for a biped robot. *IEEE Transactions on Robotics and Automation*, 2001, **17**(3): 280–289
- 4 Hu K, Ott C, Lee D. Learning and generalization of compensative zero-moment point trajectory for biped walking. *IEEE Transactions on Robotics*, 2016, **32**(3): 717–725
- 5 Kim S, Hirota K, Nozaki T, Murakami T. Human motion analysis and its application to walking stabilization with COG and ZMP. *IEEE Transactions on Industrial Informatics*, 2018, **14**(11): 5178–5186
- 6 Monje C A, Martinez S, Pierro P, Balaguer C. Whole-body balance control of a humanoid robot in real time based on ZMP stability regions approach. *Cybernetics and Systems*, 2018, **49**(7–8): 521–538
- 7 Park S, Oh J. Real-time continuous ZMP pattern generation of a humanoid robot using an analytic method based on capture point. *Advanced Robotics*, 2019, **33**(1): 33–48
- 8 Luo Lin-Cong, Hou Zeng-Guang, Wang Wei-Qun, Peng Liang. A gait trajectory adaptation algorithm based on nonlinear oscillator. *Acta Automatica Sinica*, 2016, **42**(12): 1951–1959
(罗林聪, 侯增广, 王卫群, 彭亮. 一种基于非线性振荡器的步态轨迹自适应算法. *自动化学报*, 2016, **42**(12): 1951–1959)
- 9 Duysens J, Van de Crommert H W A A. Neural control of locomotion, Part 1: The central pattern generator from cats to humans. *Gait and Posture*, 1998, **7**(2): 131–141
- 10 Grillner S, Ekeberg Ö, El Manira A, Lansner A, Parker D, Tegnér J, et al. Intrinsic function of a neuronal network — A vertebrate central pattern generator. *Brain Research Reviews*, 1998, **26**(2–3): 184–197
- 11 Ijspeert A J. Central pattern generators for locomotion control in animals and robots: A review. *Neural Networks*, 2008, **21**(4): 642–653
- 12 Wu Q D, Liu C J, Zhang J Q, Chen Q J. Survey of locomotion control of legged robots inspired by biological concept. *Science in China Series F: Information Sciences*, 2009, **52**(10): 1715–1729
- 13 Yu J Z, Tan M, Chen J, Zhang J W. A survey on CPG-inspired control models and system implementation. *IEEE Transactions on Neural Networks and Learning Systems*, 2014, **25**(3): 441–456
- 14 Ijspeert A J. A connectionist central pattern generator for the aquatic and terrestrial gaits of a simulated salamander. *Biological Cybernetics*, 2001, **84**(5): 331–348
- 15 Zhong B, Zhang S W, Xu M, Zhou Y C, Fang T, Li W H. On a CPG-based hexapod robot: AmphiHex-II with variable stiffness legs. *IEEE/ASME Transactions on Mechatronics*, 2018, **23**(2): 542–551
- 16 Wang W, Gu D B, Xie G M. Autonomous optimization of swimming gait in a fish robot with multiple onboard sensors. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2019, **49**(5): 891–903
- 17 Fukui T, Fujisawa H, Otaka K, Fukuoka Y. Autonomous gait transition and galloping over unperceived obstacles of a quadruped robot with CPG modulated by vestibular feedback. *Robotics and Autonomous Systems*, 2019, **111**: 1–19
- 18 Zhu M Z, Xu W L, Cheng L K. Esophageal peristaltic control of a soft-bodied swallowing robot by the central pattern generator. *IEEE/ASME Transactions on Mechatronics*, 2017, **22**(1): 91–98
- 19 Yu J Z, Wu Z X, Wang M, Tan M. CPG network optimization for a biomimetic robotic fish via PSO. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, **27**(9): 1962–1968
- 20 Liu C J, Xia L, Zhang C Z, Chen Q J. Multi-layered CPG for adaptive walking of quadruped robots. *Journal of Bionic Engineering*, 2018, **15**(2): 341–355
- 21 Manzoor S, Cho Y G, Choi Y. Neural oscillator based CPG for various rhythmic motions of modular snake robot with active joints. *Journal of Intelligent and Robotic Systems*, 2019, **94**(3): 641–654
- 22 Righetti L, Ijspeert A J. Programmable central pattern generators: An application to biped locomotion control. In: Proceedings of the 2006 IEEE International Conference on Robotics and Automation. Orlando, Florida, USA: IEEE, 2006. 1585–1590
- 23 Hu Y H, Liang J H, Wang T M. Parameter synthesis of coupled nonlinear oscillators for CPG-based robotic locomotion. *IEEE Transactions on Industrial Electronics*, 2014, **61**(11): 6183–6191
- 24 Kaluza P, Cioacă T. Phase oscillator neural network as artificial central pattern generator for robots. *Neurocomputing*, 2012, **97**: 115–124
- 25 Crespi A, Ijspeert A J. Online optimization of swimming and crawling in an amphibious snake robot. *IEEE Transactions on Robotics*, 2008, **24**(1): 75–87
- 26 Matsuoka K. Mechanisms of frequency and pattern control in the neural rhythm generators. *Biological Cybernetics*, 1987, **56**(5): 345–353
- 27 Liu C J, Chen Q J, Wang D W. CPG-inspired workspace trajectory generation and adaptive locomotion control for quadruped robots. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 2011, **41**(3): 867–880
- 28 Fukuoka Y, Kimura H, Cohen A H. Adaptive dynamic walking of a quadruped robot on irregular terrain based on biological concepts. *The International Journal of Robotics Research*, 2003, **22**(3–4): 187–202
- 29 Righetti L, Buchli J, Ijspeert A J. Dynamic Hebbian learning in adaptive frequency oscillators. *Physica D: Nonlinear Phenomena*, 2006, **216**(2): 269–281
- 30 Righetti L, Buchli J, Ijspeert A J. From dynamic Hebbian learning for oscillators to adaptive central pattern generators. In: Proceedings of the 3rd International Symposium on Adaptive Motion in Animals and Machines. Ilmenau, Germany: Verlag ISLE, 2005.
- 31 Sugimoto N, Morimoto J. Phase-dependent trajectory optimization for CPG-based biped walking using path integral reinforcement learning. In: Proceedings of the 11th IEEE-RAS International Conference on Humanoid Robots. Bled, Slovenia: IEEE, 2011. 255–260
- 32 Saputra A A, Botzheim J, Sulistijono I A, Kubota N. Biologically inspired control system for 3-D locomotion of a humanoid biped robot. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2016, **46**(7): 898–911
- 33 Nassour J, Hénaff P, Benouezdou F, Cheng G. Multi-layered multi-pattern CPG for adaptive locomotion of humanoid robots. *Biological Cybernetics*, 2014, **108**(3): 291–303

- 34 Kim J J, Lee J J. Gait adaptation method of biped robot for various terrains using central pattern generator (CPG) and learning mechanism. In: Proceedings of the 2007 International Conference on Control, Automation and Systems. Seoul, Korea (South): IEEE, 2007. 10–14
- 35 Aoi S, Tsuchiya K. Locomotion control of a biped robot using nonlinear oscillators. *Autonomous Robots*, 2005, **19**(3): 219–232
- 36 Nakamura Y, Mori T, Sato M A, Ishii S. Reinforcement learning for a biped robot based on a CPG-actor-critic method. *Neural Networks*, 2007, **20**(6): 723–735
- 37 Shafii N, Lau N, Reis L P. Learning to walk fast: Optimized hip height movement for simulated and real humanoid robots. *Journal of Intelligent and Robotic Systems*, 2015, **80**(3–4): 555–571
- 38 Matsubara T, Morimoto J, Nakanishi J, Sato M A, Doya K. Learning CPG-based biped locomotion with a policy gradient method. *Robotics and Autonomous Systems*, 2006, **54**(11): 911–920
- 39 Liu C J, Wang D W, Chen Q J. Central pattern generator inspired control for adaptive walking of biped robots. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2013, **43**(5): 1206–1215
- 40 Tran D H, Hamker F, Nassour J. A humanoid robot learns to recover perturbation during swinging motion. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2020, **50**(10): 3701–3712
- 41 Kalani H, Akbarzadeh A, Nabavi S N, Moghimi S. Dynamic modeling and CPG-based trajectory generation for a masticatory rehab robot. *Intelligent Service Robotics*, 2018, **11**(2): 187–205
- 42 Chopra N, Spong M W. On synchronization of Kuramoto oscillators. In: Proceedings of the 44th IEEE Conference on Decision and Control. Seville, Spain: IEEE, 2005. 3916–3922
- 43 Chiaverini S. Singularity-robust task-priority redundancy resolution for real-time kinematic control of robot manipulators. *IEEE Transactions on Robotics and Automation*, 1997, **13**(3): 398–410
- 44 Deb K, Pratap A, Agarwal S, Meyarivan T. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 2002, **6**(2): 182–197



刘成菊 同济大学电子与信息工程学院教授. 主要研究方向为仿生技术, 机器人运动控制, 进化计算. 本文通信作者.
E-mail: liuchengju@tongji.edu.cn.

(**LIU Cheng-Ju** Professor at the College of Electronic and Information Engineering, Tongji University. Her research interest covers bionics, robot motion control, and evolutionary computation. Corresponding author of this paper.)



耿皖东 同济大学电子与信息工程学院硕士研究生. 主要研究方向为仿生技术, 机器人运动控制.

E-mail: gengwandong@foxmail.com
(**GENG Wan-Dong** Master student at the College of Electronic and Information Engineering, Tongji University. His research interest covers bionics and robot motion control.)



张长柱 同济大学电子与信息工程学院副教授. 主要研究方向为智能控制, 网络控制系统, 信号处理和自动驾驶.

E-mail: zhang_changzhu@tongji.edu.cn
(**ZHANG Chang-Zhu** Associate professor at the College of Electronic and Information Engineering, Tongji University. His research interest covers intelligent control, networked control systems, signal processing, and autonomous driving.)



陈启军 同济大学电子与信息工程学院教授. 主要研究方向为机器人运动控制, 智能控制, 嵌入式系统.

E-mail: qjchen@tongji.edu.cn
(**CHEN Qi-Jun** Professor at the College of Electronic and Information Engineering, Tongji University. His research interest covers robot motion control, intelligent control, and embedded systems.)